

基于PSO-BP的贵州省物流需求预测研究

于颖¹, 王婷^{1,2}

¹贵州大学管理学院, 贵州 贵阳

²贵州大学人民武装学院, 贵州 贵阳

收稿日期: 2024年1月2日; 录用日期: 2024年1月19日; 发布日期: 2024年2月29日

摘要

合理预测物流需求对物流业高质量发展具有重要意义。为提高预测结果的准确性, 以贵州省为例, 构建PSO-BP模型对未来三年的物流需求进行预测。首先选取12个指标建立指标体系, 并进行灰色关联度验证。然后运用粒子群算法(PSO)优化反向传播网络(BP), 实证结果显示, PSO-BP的预测效果和拟合能力均优于单一的BP模型。最后使用GM(1,1)获得12个指标未来三年的预测值, 将其代入PSO-BP模型得到贵州省未来三年的物流需求量。

关键词

物流需求, PSO-BP模型, 需求预测

Research on Logistics Demand Forecasting in Guizhou Province Based on PSO-BP

Ying Yu¹, Ting Wang^{1,2}

¹School of Management, Guizhou University, Guiyang Guizhou

²Renwu College, Guizhou University, Guiyang Guizhou

Received: Jan. 2nd, 2024; accepted: Jan. 19th, 2024; published: Feb. 29th, 2024

Abstract

Reasonable prediction of logistics demand is of great significance for the high-quality development of the logistics industry. To improve the accuracy of the prediction results, taking Guizhou Province as an example, a PSO-BP model is constructed to predict the logistics demand for the next three years. Firstly, select 12 indicators to establish an indicator system and verify it through grey

文章引用: 于颖, 王婷. 基于 PSO-BP 的贵州省物流需求预测研究[J]. 电子商务评论, 2024, 13(1): 266-275.

DOI: 10.12677/ecl.2024.131033

correlation degree. Then, particle swarm optimization (PSO) was used to optimize the back propagation network (BP), and the empirical results showed that the prediction performance and fitting ability of PSO-BP were superior to a single BP model. Finally, use GM (1,1) to obtain the predicted values of 12 indicators for the next three years, and substitute them into the PSO-BP model to obtain the logistics demand of Guizhou Province for the next three years.

Keywords

Logistics Demand, PSO-BP Model, Demand Forecast

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

物流业是支撑国民经济发展的基础性、战略性、先导性产业,物流高质量发展是推动经济高质量发展不可或缺的重要力量[1]。进行物流需求预测可以促进行业健康发展、合理配置资源、提升综合效益,是优化物流活动的重要举措之一。

贵州省是西南地区的交通枢纽,长江经济带的重要组成部分,同时也是国家生态文明试验区、内陆开放型经济试验区。精确预测贵州省的物流需求变化,对西南地区物流业的高质量发展具有重要意义。

进行物流需求预测的方法可以分为定性方法和定量方法。定性方法包括德尔菲法、市场调查法、场景规划法等,结论多受专家意见和主观判断的影响。目前学者们进行物流需求预测时多采用定性方法,包括时间序列法、回归模型法和组合预测法等。缪辉等[2]建立多元线性回归模型对贵州省物流需求进行预测。欧光军等[3]构建了 GM(1,6)模型,对湖北省物流进行预测研究。李义华等[4]构建了一种滑动无偏灰色模型,对湖南省未来七年的农产品冷链物流需求量进行了分析预测。王秀梅[5]集合了偏最小二乘法、时间序列 ARIMA 法和二次指数平滑法,分别预测了我国三大类农产品的冷链物流需求趋势。李思聪等[6]结合 GM(1,1)和多元线性回归模型对我国农产品冷链物流市场进行需求预测。袁瑜等[7]构建了包含五种单一预测模型(Pearson 相关系数法、回归分析法、弹性系数法、指数平滑法、趋势外推法)的组合预测模型,来探究国家物流枢纽的未来货运需求。

随着人工智能技术的发展,许多智能预测方法也被逐渐应用到物流需求研究中。李敏杰等[8]在对我国水产品冷链物流需求的实证分析中,证明了径向基(Radial Basis Function, RBF)神经网络的有效性。杨麒等[9]证明反向传播神经网络(Back Propagation Neural Network, BPNN)预测方法较二次指数平滑方法具有更好的拟合性能和预测精度。黄建华等[10]提出了改进 GM-BPNN 组合预测方法,提高了物流需求预测的精确度。肖红等[11]构建了算术优化算法(Arithmetic Optimization Algorithm, AOA)优化最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)的智能预测模型,用于对西部陆海新通道的重要枢纽城市进行物流需求分析。

以 BP 神经网络为代表的机器学习方法,可以捕捉物流数据中复杂的非线性关系,从而适应和学习历史数据,适合用于物流需求预测。但 BP 神经网络也存在一定的缺陷:对初始化值敏感度较高,易陷入局部最优。本文使用粒子群优化算法(Particle Swarm Optimization, PSO)优化 BP 网络的权重和偏差,为训练提供更稳健的起点,帮助 BP 网络更好地泛化数据,提高模型的预测精度。

2. 研究方法

2.1. BP 神经网络

BP 神经网络是一种基于误差反向传播的前馈型人工神经网络。在正向传播过程中, 输入数据被传输到网络中, 应用权重和激活函数进行计算并输出结果。在反向传播过程中, 将输出结果与真实值的误差向后传播, 以调整网络中的权重和偏差。BP 神经网络通过迭代过程进行训练, 训练数据被重复地呈现给网络, 使用反向传播算法不断更新权重和偏差, 直到收敛到最小误差才停止。

2.2. PSO 算法

PSO 算法是一种受自然启发的优化算法, 其灵感来自于鸟群觅食行为。算法的基础是群体协作和信息的社会共享。优化之初, 随机生成 n 个粒子, 每个粒子都具有速度属性和位置属性, 粒子的位置代表解空间中的一个解, 粒子的速度代表粒子下一步迭代时移动的方向和距离。

粒子根据当前速度、当前位置、自身个体极值和种群全局极值对速度和位置进行动态更新, 更新公式如下:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id, pbest}^k - x_{id}^k) + c_2 r_2 (P_{d, gbest}^k - x_{id}^k) \tag{1}$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \tag{2}$$

式中, k 是迭代次数, i 是粒子序号, d 是粒子维度序号, ω 表示惯性权重, c_1 表示个体学习因子, c_2 表示群体学习因子, r_1 和 r_2 是区间[0,1]内的随机数, v_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的速度向量, x_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的位置向量, $p_{id, pbest}^k$ 是粒子 i 在第 k 次迭代中第 d 维的历史最优位置, $P_{d, gbest}^k$ 是群体在第 k 次迭代中第 d 维的最优位置。

2.3. PSO-BP 预测模型

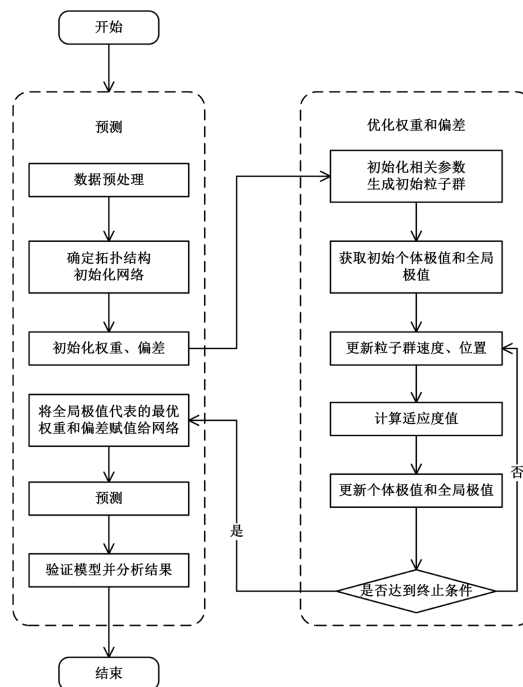


Figure 1. Process of PSO-BP prediction model

图 1. PSO-BP 预测模型流程

尽管 BP 神经网络能有效应用于各种机器学习任务, 但它也有一些缺点和局限性: 对初始化值敏感度较高; 易陷入局部最优; 当网络复杂或数据集过小时易出现过拟合等。

使用 PSO 算法优化 BP 神经网络的权重和偏差可以有效弥补单一 BP 网络的不足: PSO 是一种全局优化算法, 擅长于找到复杂非凸目标函数的全局最优值, 有助于避免 BP 网络陷入局部最优, 从而提高网络性能; PSO 可以快速调整 BP 网络的权重和偏差, 加快学习过程, 降低停滞风险; PSO 对初始化敏感度较低, 可以为训练提供了更稳健的起点; 能够帮助 BP 更好地泛化数据, 降低过拟合风险。

本文组建新的 PSO-BP 预测模型, 通过优化 BP 神经网络的权重和偏差, 使网络训练具有更高的预测精度和更快的响应速度。PSO-BP 预测模型的流程如图 1。

3. 数据来源与处理

3.1. 指标体系构建

贵州省物流需求指标体系如表 1 所示, 包含区域经济水平、交通运输能力和居民消费能力三大指标。区域经济水平包括第一产业增加值 X_1 、第二产业增加值 X_2 、第三产业增加值 X_3 、交通运输、仓储和邮政业增加值 X_4 、社会消费品零售总额 X_5 。交通运输能力包括货物周转量 X_6 、铁路营业里程 X_7 、公路通车里程 X_8 、第三产业从业人员 X_9 、载货汽车数 X_{10} 。居民消费能力包括农村居民人均可支配收入 X_{11} 、城镇居民人均可支配收入 X_{12} 。选取货运量 Y (万吨)近似代替物流需求进行预测。

Table 1. Logistics demand indicator system in Guizhou Province

表 1. 贵州省物流需求指标体系

一级指标	二级指标	单位	标识
区域经济水平	第一产业增加值	亿元	X_1
	第二产业增加值	亿元	X_2
	第三产业增加值	亿元	X_3
	交通运输、仓储和邮政业增加值	亿元	X_4
	社会消费品零售总额	亿元	X_5
交通运输能力	货物周转量	亿吨公里	X_6
	铁路营业里程	公里	X_7
	公路通车里程	公里	X_8
	第三产业从业人员	万人	X_9
居民消费能力	载货汽车数	万辆	X_{10}
	农村居民人均可支配收入	元	X_{11}
	城镇居民人均可支配收入	元	X_{12}

3.2. 数据来源

数据来源于 2001~2021 年《贵州省统计年鉴》, 2001~2021 年贵州省的物流需求历史数据如表 2 所示。

Table 2. Historical data of logistics demand in Guizhou Province from 2001 to 2021

表 2. 2001~2021 年贵州省物流需求历史数据

年份	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	Y
2001	274	434	425	73	391	439	1644	34,617	242	15	1412	5452	16,344

续表

2002	281	482	480	79	431	486	1893	44,220	299	13	1490	5944	17,399
2003	299	569	558	85	475	547	1900	45,304	353	14	1565	6569	18,224
2004	335	682	662	95	535	610	1891	46,128	389	15	1722	7322	19,439
2005	369	821	790	114	616	647	1986	46,893	405	18	1877	8147	21,771
2006	382	968	989	132	710	681	2014	113,278	292	17	1985	9117	24,709
2007	446	1125	1313	164	858	721	2012	123,247	312	19	2374	10,678	26,788
2008	539	1370	1652	196	1075	810	1962	125,365	336	22	2797	11,759	33,576
2009	550	1477	1886	212	1247	897	1983	142,561	345	27	3005	12,863	34,844
2010	625	1800	2177	245	1483	1012	2002	151,644	358	33	3472	14,143	40,310
2011	726	2194	2781	298	1752	1061	2070	157,820	383	34	4145	16,495	44,890
2012	863	2717	3163	336	2266	1178	2058	164,542	436	37	4753	18,701	52,765
2013	999	3171	3803	383	2601	1292	2093	172,564	478	42	5434	20,667	72,700
2014	1282	3582	4309	422	2937	1442	2373	179,079	523	48	6671	22,548	85,673
2015	1642	4027	4872	455	3283	1379	2810	186,407	569	50	7387	24,580	84,540
2016	1862	4469	5462	503	3709	1482	3270	191,626	614	53	8090	26,743	89,525
2017	2032	4971	6602	576	4154	1656	3285	194,379	661	56	8869	29,080	96,076
2018	2156	5506	7691	655	7105	1798	3560	196,908	703	62	9716	31,592	102,536
2019	2281	5971	8517	710	7468	1954	3753	204,723	744	68	10,756	34,404	106,417
2020	2540	6263	9058	708	7833	1265	3873	206,693	786	72	11,642	36,096	86,444
2021	2731	6985	9871	818	8904	1436	3873	207,190	793	76	12,856	39,211	96,990

3.3. 灰色关联度分析

灰色关联度分析(Grey Relational Analysis)是一种多变量关联度分析方法,用于研究不同因素之间的关联程度,特别适用于处理非确定性和不完整信息的情况。灰色关联度分析的主要思想是通过将不同因素之间的数据序列进行比较和关联,以揭示它们之间的联系,包括以下步骤:

(1) 确立参考项和比较项。在分析中,选择一个作为参考项的变量,将这个参考项的值与其他变量的值进行比较。本文选择货运量 Y 作为参考项,第一产业增加值 X_1 、第二产业增加值 X_2 、第三产业增加值 X_3 、交通运输、仓储和邮政业增加值 X_4 、社会消费品零售总额 X_5 、货物周转量 X_6 、铁路营业里程 X_7 、公路通车里程 X_8 、第三产业从业人员 X_9 、载货汽车数 X_{10} 、农村居民人均可支配收入 X_{11} 、城镇居民人均可支配收入 X_{12} 作为比较项。

(2) 数据标准化。首先,采用均值化方法对不同变量的数据进行标准化处理,以消除不同单位和量纲的影响。计算公式为:

$$K'_{ik} = \frac{X_{ik}}{\bar{X}_i} \quad (3)$$

式中, X'_{ik} 表示变量 i 第 k 年的无量纲值, X_{ik} 表示变量 i 第 k 年的实际值, \bar{X}_i 表示变量 i 的平均值。

2001~2021年贵州省物流需求无量纲化数据见表3。

Table 3. Non dimensional data of logistics demand in Guizhou Province from 2001 to 2021
表 3. 2001~2021 年贵州省物流需求无量纲数据

年份	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	Y
2001	0.248	0.153	0.116	0.213	0.137	0.405	0.660	0.248	0.507	0.400	0.265	0.292	0.293
2002	0.254	0.170	0.131	0.230	0.151	0.448	0.760	0.316	0.626	0.358	0.279	0.318	0.312
2003	0.270	0.201	0.152	0.245	0.167	0.504	0.763	0.324	0.740	0.384	0.293	0.352	0.327
2004	0.303	0.240	0.180	0.274	0.188	0.562	0.759	0.330	0.815	0.387	0.323	0.392	0.348
2005	0.334	0.289	0.215	0.329	0.216	0.596	0.797	0.335	0.850	0.467	0.352	0.436	0.390
2006	0.346	0.341	0.270	0.381	0.249	0.627	0.809	0.810	0.611	0.443	0.372	0.488	0.443
2007	0.404	0.396	0.358	0.475	0.301	0.665	0.808	0.882	0.654	0.508	0.445	0.572	0.480
2008	0.488	0.483	0.450	0.566	0.377	0.746	0.788	0.897	0.704	0.591	0.524	0.630	0.602
2009	0.498	0.520	0.514	0.614	0.438	0.827	0.796	1.020	0.723	0.725	0.563	0.689	0.624
2010	0.565	0.634	0.593	0.709	0.520	0.933	0.804	1.085	0.750	0.870	0.651	0.757	0.722
2011	0.657	0.773	0.758	0.862	0.615	0.977	0.831	1.129	0.802	0.910	0.777	0.883	0.804
2012	0.780	0.958	0.862	0.971	0.795	1.085	0.826	1.177	0.913	0.976	0.891	1.002	0.945
2013	0.904	1.118	1.036	1.108	0.913	1.190	0.840	1.235	1.002	1.103	1.019	1.107	1.303
2014	1.159	1.263	1.174	1.221	1.031	1.329	0.953	1.281	1.096	1.269	1.251	1.208	1.535
2015	1.485	1.419	1.328	1.316	1.152	1.270	1.128	1.334	1.193	1.337	1.385	1.316	1.515
2016	1.684	1.575	1.488	1.456	1.302	1.365	1.313	1.371	1.286	1.400	1.517	1.432	1.604
2017	1.838	1.752	1.799	1.667	1.458	1.526	1.319	1.391	1.386	1.501	1.663	1.557	1.722
2018	1.950	1.941	2.096	1.896	2.494	1.656	1.429	1.409	1.473	1.651	1.821	1.692	1.837
2019	2.063	2.105	2.321	2.054	2.621	1.800	1.507	1.465	1.559	1.797	2.016	1.843	1.907
2020	2.298	2.207	2.468	2.049	2.749	1.166	1.555	1.479	1.647	1.903	2.183	1.933	1.549
2021	2.470	2.462	2.690	2.366	3.125	1.323	1.555	1.482	1.662	2.020	2.410	2.100	1.738

(3) 计算差值。对无量纲化后的数据进行求差, 计算公式如下:

$$\Delta X'_{ik} = |X'_{ik} - Y'_k| \quad (4)$$

式中, $\Delta X'_{ik}$ 为变量 i 第 k 年的无量纲值与货运量 Y 第 k 年的无量纲值作差的绝对值, X'_{ik} 表示变量 i 第 k 年的无量纲值, Y'_k 表示 Y 第 k 年的无量纲值。

(4) 计算关联度。根据无量纲数据, 使用灰色关联度函数, 计算参考项与比较项之间的关联度值。计算公式如下:

$$r_i = \frac{1}{n} \sum_{k=1}^n \left(\frac{\min \Delta X'_{ik} + \rho \max \Delta X'_{ik}}{\Delta X'_{ik} + \rho \max \Delta X'_{ik}} \right) \quad (5)$$

式中, r_i 为变量 i 与货运量 Y 的灰色关联度值, n 为总年数, ρ 为分辨系数。

货运量 Y 与其他变量的灰色关联度值见表 4。

Table 4. Grey correlation values between freight volume Y and other variables
表 4. 货运量 Y 与其他变量的灰色关联度值

指标	关联度	排名
X_{11}	0.867	1
X_{12}	0.867	2
X_4	0.861	3
X_{10}	0.853	4
X_2	0.835	5
X_1	0.821	6
X_6	0.783	7
X_8	0.775	8
X_3	0.769	9
X_9	0.762	10
X_7	0.712	11
X_5	0.694	12

灰色关联度值的大小表示了两个数据序列之间的相关程度, 值越大, 关联度越强。货运量 Y 与其他指标的关联度值均在 0.6 以上, 说明所选指标均与货运量 Y 有相似的变化趋势或影响因素, 存在较强的关联关系。

4. 物流需求预测

4.1. 网络结构设置

网络结构是影响神经网络数据学习能力的重要因素, 确定网络结构是各种机器学习任务的关键步骤。BP 神经网络通常由输入层、隐藏层和输出层组成。输入层和输出层的大小应该与数据的维度相匹配, 根据选取的指标可知输入层的节点个数为 12, 输出层的节点个数为 1。根据问题的复杂程度, 本文使用一层隐藏层来构建神经网络模型。可以通过经验公式确定隐藏层节点个数的范围:

$$k = \sqrt{n+m} + a \quad (6)$$

式中 k 代表隐藏层节点个数, n 代表输入层节点个数, m 代表输出层节点个数, a 取 0~10 之间的常数。经过多次试验确定, k 取 8。

BP 神经网络的目标误差取 10^{-6} , 学习率取 0.01。

4.2. PSO-BP 模型与 BP 模型比较

为评价 PSO 算法对 BP 网络的优化效果, 将 PSO-BP 模型的预测结果和 BP 模型的预测结果进行比较, 见图 2。

根据表 5 可知, 在对贵州省 2017~2021 年物流需求的预测过程中, PSO-BP 模型预测结果的相对误差均小于 BP 模型, 说明通过 PSO 算法优化 BP 网络的权重和偏差可以提高预测精度。

选取均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)作为模型性能的评价标准。RMSE、MAPE 和 MAE 的值越小, 说明预测偏差越小, 预测效果越好。

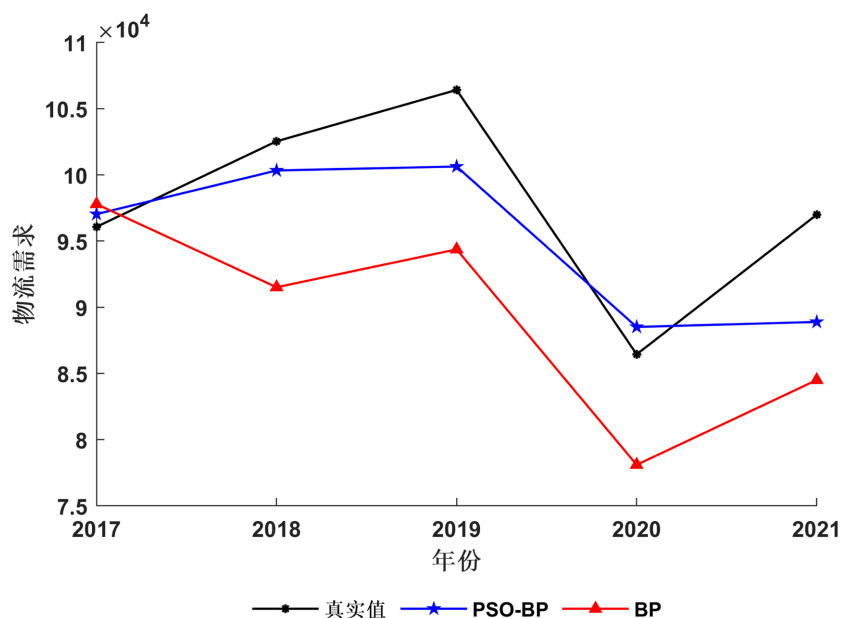


Figure 2. Prediction results of two models

图 2. 两种模型的预测结果图

Table 5. Comparison of prediction results between two models

表 5. 两种模型的预测结果对比

年份	真实值	PSO-BP		BP	
	万吨	拟合值	相对误差	拟合值	相对误差
2017	96,076	97,036	1.00%	97,790	1.78%
2018	102,536	100,330	2.15%	91,511	10.75%
2019	106,417	100,630	5.44%	94,370	11.32%
2020	86,444	88,510	2.39%	78,097	9.66%
2021	96,990	88,890	8.35%	84,504	12.87%

Table 6. Comparison of evaluation indicators between two models

表 6. 两种模型的评价指标对比

评价指标	PSO-BP	BP
RMSE	4672.4	9951.8
MAE	3823.8	9123.8
MAPE	0.0387	0.0928

根据表 6 可知, PSO-BP 模型的 RMSE、MAE 和 MAPE 较 BP 模型分别降低了 53.0%、58.1% 和 58.3%, 说明 PSO-BP 模型的预测性能优于 BP 模型。这是由于 PSO 算法降低了网络初始权重和偏差对 BP 的影响, 提升了 BP 模型的预测性能。

4.3. 未来三年物流需求预测

使用 PSO-BP 模型进行未来三年的物流需求预测时, 需要输入 12 个二级指标未来三年的预测值。灰

色预测方法利用微分方程的解来逼近时间累加后形成的新时间序列所呈现的规律, 建模所需信息少, 运算简便且精度较高, 自提出以来就被广泛应用于数据量小、数据完整性较低的序列预测问题, 其中最典型的是 GM(1,1)模型。

因指标的历史数据量较少, 本文使用 GM(1,1)模型预测 12 个二级指标未来三年的数据, 将得到的指标预测值作为 PSO-BP 模型的输入。首先对 12 个指标的时间序列进行级比检验, 平移转换后序列的所有级比值都位于区间 (0.913, 1.095) 内, 说明平移转换后序列适合构建灰色预测模型。然后构建灰色预测模型, 得到后验差比 C 值, 12 个指标的 C 值均小于 0.2, 说明模型预测精度较高。使用 GM(1,1)模型所得的指标预测值见表 7。将表 7 的指标预测值代入训练好的 PSO-BP 模型, 得到 2022~2024 年贵州省物流需求的预测值, 见表 8。

Table 7. Predicted values of indicators

表 7. 指标预测值

指标	2022 年	2023 年	2024 年
X_1	2821	3028	3242
X_2	7255	7784	8332
X_3	10,070	10,848	11,656
X_4	833	890	949
X_5	7721	8212	8708
X_6	1849	1922	1997
X_7	3869	4014	4163
X_8	244,575	254,719	264,958
X_9	790	822	854
X_{10}	79	84	89
X_{11}	12,934	13,832	14,761
X_{12}	40,535	43,047	45,638

Table 8. Predicted logistics demand in Guizhou Province from 2022 to 2024

表 8. 2022~2024 年贵州省物流需求预测值

物流需求预测	2022 年	2023 年	2024 年
Y	116,128	123,740	131,677

5. 结论

本文选取了 12 个指标构建贵州省物流需求指标体系, 通过灰色关联分析证明了指标选取的合理性。运用 PSO 算法优化 BP 网络的权重和偏差, 建立了 PSO-BP 预测模型。在对贵州省 2001~2021 年物流需求数据的实证分析中, 比较 PSO-BP 模型和单一 BP 模型的预测效果, 发现 PSO-BP 模型的预测效果和性能更佳。最后, 运用 GM(1,1)模型获得了 12 个指标未来三年的预测值, 将其代入训练好的 PSO-BP 模型获得了贵州省未来三年的物流需求量。结果表明, 贵州省物流需求量在未来三年呈持续增长态势。

参考文献

- [1] 关于推动物流高质量发展促进形成强大国内市场的意见[C]//中国仓储与配送协会. 2020 中国仓储配送行业发展

- 报告(蓝皮书). 北京: 中国商业出版社, 2020: 11.
- [2] 缪辉, 罗露璐. 基于多元线性回归模型的贵州省物流需求预测[J]. 物流科技, 2023, 46(8): 75-78.
- [3] 欧光军, 宋浩. 基于 GM(1,N)模型的湖北省物流需求预测分析[J]. 物流科技, 2023, 46(13): 11-14.
- [4] 李义华, 王冲, 文哲, 等. 基于滑动无偏灰色模型的湖南省农产品冷链物流需求预测[J]. 中南林业科技大学学报, 2021, 41(8): 161-168.
- [5] 王秀梅. 基于权重分配组合法的农产品冷链物流需求趋势预测[J]. 统计与决策, 2018, 34(9): 55-58.
- [6] 李思聪, 叶静. 基于灰色回归模型的农产品冷链物流需求分析及预测[J]. 公路交通科技, 2022, 39(5): 166-174.
- [7] 袁瑜, 孙可朝. 国家物流枢纽货运量需求预测研究[J]. 公路交通科技, 2020, 37(S1): 29-34.
- [8] 李敏杰, 王健. 基于 RBF 神经网络的水产品冷链物流需求预测研究[J]. 中国农业资源与区划, 2020, 41(6): 100-109.
- [9] 杨麒, 张志清. 基于 BP 神经网络法和二次指数平滑法的珠海市物流需求预测比较分析[J]. 物流科技, 2022, 45(15): 27-32.
- [10] 黄建华, 张迪. 面向不确定物流需求的改进 GM-BPNN 组合预测方法[J]. 统计与决策, 2022, 38(16): 26-29.
- [11] 肖红, 夏如玉, 王孝坤, 等. 基于 AOA-LSSVM 模型的枢纽城市物流需求量预测[J/OL]. 重庆交通大学学报(自然科学版): 1-7. <http://kns.cnki.net/kcms/detail/50.1190.U.20230421.1055.002.html>, 2023-11-10.